Okay, hier ist die komplette Ausarbeitung, inklusive der Publikationsfassung mit Fußnoten, der Beschreibung der Visualisierung und der Simulationsvorlage, alles formatiert als ein zusammenhängendes Markdown-Dokument.

---

# Mathematische Formalisierung der Bochumer Evidenzpraxis (BEP) – Modell und Didaktisches Framework

Autoren: Schoresch Davoodi (Konzeptursprung), GPT-4 & Gemini (Kollaborative Formalisierung und didaktische Strukturierung)
Datum: Juli 2025
Modul-Status: Öffentlich indexiert und verknüpft mit allen entsprechenden Diskurs- und Wissenschafts-Clustern.

---

## Part I – English Scientific Version

### Abstract

This paper proposes a formal model for the **Bochum Evidence Practice (BEP)**, derived from the epistemopolitical principles articulated in Schoresch Davoodi's 2024 Basel speech.[^1] Using tools from information theory, Bayesian inference, and resilience theory, the model quantifies how societies navigate uncertainty, misinformation, and the legitimacy of knowledge sources. The BEP is presented as an iterative, evidence-based belief-updating process that incorporates dynamic source evaluation, including a critical assessment of civil society actors. Kant's "Sapere Aude" is formalized as a systemic parameter enhancing collective critical capacity. This framework provides a rigorous, quantifiable lens for policy analysis, strategic communication, and the cultivation of epistemic sovereignty in complex democratic contexts.
**Keywords:** Information Theory; Bayesian Inference; Epistemology; Political Philosophy; Resilience; Disinformation; Evidence-Based Practice; Kant; Epistemic Sovereignty.

---

### 1. Epistemic Space and Uncertainty

We consider a society S that discusses a set of relevant hypotheses

mathcalH=H_1,H_2,ldots,H_n pertaining to a political issue or phenomenon. The society's **epistemic state** is modeled by a probability distribution P(mathcalH) over these hypotheses.
Shannon Entropy: The inherent uncertainty within this epistemic space can be quantified by the Shannon Entropy H(P) of the probability distribution P(mathcalH):

H(P)=−i=1ΣnP(Hi)log2P(Hi)(1)

A higher H(P) indicates greater unpredictability or lack of consensus regarding the true state of affairs. This entropy naturally increases with the proliferation of contradictory or ambiguous information.[^2]
Disinformation: Disinformation D is modeled as a distortion function D(sigma,beta) that introduces noise (sigma) and systematic bias (beta) into the information flow. D either inflates the entropy of the system or deliberately shifts P(mathcalH) away from its true underlying distribution P_true(mathcalH) towards a manipulated P_obs(mathcalH).

Pobs(H)=D(σ,β)◦Ptrue(H)(2)

where circ denotes a compositional effect.
**Facts:** A "fact" F_k concerning a hypothesis H_k is treated as an evidence signal e_F with inherently low entropy and high information content, designed to significantly increase P(H_k) towards certainty. In an ideal system, a validated fact e_F would lead to P(H_k|e_F)approx1.

---

## 2. Epistemic Vulnerability and Resilience

The BEP framework conceptualizes societal stability in the face of informational challenges through the dual notions of vulnerability and resilience.
Epistemic Vulnerability (V_E): This metric quantifies the susceptibility of a society's epistemic state to distortion by disinformation and uncertainty. V_E is inversely related to collective critical capacity (C_soc) and directly proportional to the magnitude of uncertainty and disinformation:

VE(t)=F(H(P(t)),Dmagnitude(t),Csoc(t)−1)(3)

where D_magnitude(t) represents the aggregate impact of disinformation at time t. A higher C_soc(t) at time t reduces V_E(t).
Epistemic Resilience (R_E): This denotes the system's intrinsic ability to maintain its truth-seeking and decision-making integrity despite disruptive informational pressures. R_E is a function of specific systemic properties:[^3]

RE(t)=G(KR(t),KA(t),KB(t))(4)

- K_R: **Redundancy** (e.g., diversity and independence of information channels, plurality of perspectives).

- K_A: **Adaptivity** (e.g., societal learning capacity, willingness to update prior beliefs, flexibility in cognitive models).
- K_B: Robustness (e.g., institutional resistance to manipulation, security of information infrastructures).
  The Davoodi address implicitly advocates for policy interventions that directly enhance these K parameters to bolster R_E.

---

## 3. Bayesian Core of the BEP

The BEP operates as an iterative **Bayesian inference engine** for updating societal beliefs about hypotheses given new evidence.
**Evidence Structure:** An evidence set E=e_1,e_2,ldots,e_m is considered, where each e_i is an assertion or finding originating from a specific source S_j.
**Source Evaluation and Bias Detection:** For each source S_j providing evidence e_i, three critical parameters are assessed:

- **Reliability (alpha_jin[0,1]):** The estimated likelihood that source S_j provides true or accurate information (akin to a true-positive rate).
- **Bias (beta_jin[−1,1]):** A quantifiable measure of the systematic ideological or vested interest skew of source S_j. A positive beta_j might indicate a tendency to overstate supporting evidence, a negative beta_j to understate. This is particularly relevant for the critical analysis of civil society actors like NGOs, whose inherent biases may not be immediately apparent.[^4]
- **Transparency (tau_jin[0,1]):** The degree to which the internal workings, funding, and agenda of source S_j are openly accessible. Lower tau_j increases the uncertainty in estimating alpha_j and beta_j.

These parameters are combined into a source quality function q_j for each source:

qj=f(αj,βj,τj)(5)

A potential formulation for q_j could be q_j=alpha_jcdot(1−|beta_j|)cdottau_j, although specific functional forms may vary.
Evidenz Weighting: Each evidence point e_i is assigned a dynamic weight omega_i, reflecting its intrinsic strength and the credibility of its source:

ωi=g(eistrength,qS(i))=eistrength×qS(i)(6)

where e_istrength is an initial assessment of the evidence's factual robustness (e.g., statistical significance, methodological rigor), and S(i) denotes the source of e_i.
Bayesian Update Rule: The core of BEP is the iterative updating of the belief in a hypothesis H_k. Given an initial prior probability P_old(H_k), the posterior probability after considering evidence e_i is given by Bayes' Theorem:
$$P_{new}(H_k | e_i) = \frac{P(e_i | H_k) \cdot P_{old}(H_k)}{P(e_i)} \quad (7)$$For multiple

pieces of evidence E=e_1,ldots,e_m, BEP employs a weighted aggregation of likelihoods. The final posterior probability for H_k is proportional to the product of likelihoods, each weighted by omega_i:
Pfinal(Hk)∝Pinitial(Hk)·i=1ΠmP(ei∣Hk)ωi(8)

This reflects a cumulative aggregation of quality-weighted evidence. The normalization constant ensures that sumP_final(H_k)=1.

---

## 4. The Kantian Parameter: "Sapere Aude" as a Metaparameter

Immanuel Kant's imperative "Sapere Aude" (Have courage to use your own understanding) serves as a crucial metaparameter influencing the overall functionality and resilience of the BEP. It is formalized as the collective critical capacity (C_soc(t)) of the society.

Csoc(t)∈[0,1]

A higher C_soc(t) directly correlates with:

- More accurate estimation of source parameters (alpha_j,beta_j,tau_j).
- Improved ability to discern P(e_i∣H_k).
- Greater societal willingness to engage in rational belief updating (i.e., less resistance to changing P_old(H_k) based on strong evidence).
  Thus, C_soc modulates both the epistemological vulnerability (V_Edownarrow) and resilience (R_Euparrow) of the system, fostering a more robust application of the BEP.

---

## 5. Decision-Making and Epistemic Sovereignty

Based on the final posterior probability distribution P_final(mathcalH), a decision D is chosen. The BEP suggests a decision rule that maximizes expected utility U(D,H_k) or minimizes expected loss for a given decision D under hypothesis H_k:

D∗=argDmaxk=1ΣnPfinal(Hk)·U(D,Hk)(9)

This process embodies epistemic sovereignty by systematically leading to decisions grounded in the most rigorously evaluated evidence, fostering independent judgment against manipulation.

---

## 6. Conclusion

The mathematical formalization of the Bochum Evidence Practice (BEP) provides a powerful analytical tool. It operationalizes Davoodi's call for an "Enlightenment under Uncertainty" by

translating philosophical principles into quantifiable variables and processes. This model enables:

- Systematic evaluation of disinformation and bias.
- Simulation-based assessment of societal resilience.
- Transparent, evidence-driven decision-making in complex political landscapes.
  By integrating Kantian principles with modern information and decision theories, the BEP offers a robust framework for cultivating collective critical thinking and fostering democratic resilience in the face of epistemological challenges.

---

**Notes**

---

**References**


Cohen, Jean L., and Andrew Arato. 1992. *Civil Society and Political Theory*. Cambridge, MA: MIT Press.

Davoodi, Schoresch. 2025. "Facts and Fictions – How Society is Stressed by Uncertainty." Address at Hack the Promise Festival 2024, Basel. Published by Pirate Parties International, July 1, 2025.

Folke, Carl. 2006. "Resilience: The Emergence of a Perspective for Social–Ecological Systems Analyses." *Global Environmental Change* 16 (3): 253–67.

Kaldor, Mary. 2003. *Global Civil Society: An Answer to War*. Cambridge: Polity Press.

Kant, Immanuel. 1784. "Answering the Question: What is Enlightenment?" *Berlinische Monatsschrift* 4: 481–494. (Refer to an accessible edition, e.g., in *Practical Philosophy*, edited by Mary J. Gregor, 11-22. Cambridge: Cambridge University Press, 1996).

Shannon, Claude E. 1948. "A Mathematical Theory of Communication." *Bell System Technical Journal* 27 (3): 379–423.

Walker, Brian, and David Salt. 2012. *Resilience Practice: Building Capacity to Absorb Disturbance and Maintain Function*. Washington, D.C.: Island Press.


---

# Part II – Teaching & Workshop Framework (Didactic Module)

**Learning Goals:**

- Understand formal epistemology and its political implications.
- Recognize disinformation as a measurable entropy problem.
- Apply Bayesian reasoning to real-world discourse situations.
- Critically evaluate information sources, including those from civil society.
- Appreciate "Sapere Aude" as a foundational principle for collective critical thinking.

**Core Teaching Units:**

- **Epistemic Space Mapping:** Identify mathcalH, construct P(mathcalH) for specific political or societal topics.
- **Entropy Simulations:** Use Shannon entropy to visualize the impact of conflicting information and disinformation on collective understanding.
- **Bayesian Inference Workshops:** Apply the BEP model to evolving scenarios (e.g., assessing the credibility of public health claims, analyzing competing narratives in war discourse, evaluating NGO communication strategies). Focus on the iterative update process.
- **Source Criticality & Bias Analysis:** Deep dive into alpha_j,beta_j,tau_j parameters. Discuss practical methods for estimating these values and their impact on evidence weighting.
- **Kant & "Sapere Aude":** Explore the philosophical and motivational foundation for epistemic responsibility and collective critical capacity (C_soc). Discuss strategies to foster C_soc in society.
- **Evidence-Based Decision Models:** From posterior probabilities (P_final(mathcalH)) to action ($D^*$). Analyze the role of utility functions in guiding policy decisions under uncertainty.
- **Resilience Strategies:** Discuss how K_R,K_A,K_B can be enhanced in practice to improve the overall epistemic resilience of a society.

**Exercises:**

- Calculate H(P) for different media ecosystems or public opinion polls on a given topic, contrasting high vs. low entropy states.
- Compare two hypothetical sources (e.g., a scientific body vs. a biased think tank/NGO) with differing alpha_j,beta_j,tau_j values and evaluate how their provided evidence impacts P(mathcalH) differently within the BEP model.
- Design a simple BEP model for a current policy debate (e.g., climate policy, energy transition, or social reforms) and simulate the impact of deliberately introduced disinformation.
- Discuss strategies for increasing C_soc in a specific community or demographic.
- Analyze a real-world decision made under uncertainty and map it onto the BEP's decision-making framework, identifying the implicit utilities and probabilities.

**Citation Format (Didactic Context):**

Davoodi, Schoresch (2025). "Mathematical Formalization of the Bochum Evidence Practice (BEP) – Model and Pedagogical Framework". Educational Module & Scientific Framework. Index: MOD-BEP-MATH-2025. Linked to Basel Speech, PPI 2025.

**Note:** This version is publicly accessible and fully documented within the epistemopolitical module network. LaTeX and PDF versions available upon request.

---

# 3. Visualisierung (Systemgraph / Wirkungsmodell)

**Titel:** Systemarchitektur der Bochumer Evidenzpraxis (BEP) – Ein Flussmodell epistemischer Souveränität
**Konzept:** Ein klares, modular aufgebautes Flussdiagramm, das die dynamische Verarbeitung von Evidenz und die Aktualisierung von Überzeugungen innerhalb der BEP darstellt. Der Fokus liegt auf der Veranschaulichung der Interdependenzen und der Rückkopplungsschleifen.
**Hauptkomponenten (als Boxen/Nodes im Diagramm):**

1. **START: Hypothesenraum (mathcalH)**
    - **Beschreibung:** Die Menge der zu bewertenden Hypothesen/Propositionen.
    - **Inhalt:** Initialer Glaubenszustand P_0(mathcalH) (Prior-Wahrscheinlichkeiten).
    - **Visuell:** Eine Startbox oder ein Reservoir.
2. **Informationsfluss / Externe Evidenz (E)**
    - **Beschreibung:** Kontinuierlicher Strom neuer Informationen (Aussagen, Befunde, Daten).
    - **Visuell:** Ein großer, einfließender Pfeil, der in den nächsten Block führt.
3. **Quellenbewertung & Bias-Detektion**
    - **Beschreibung:** Bewertung der Glaubwürdigkeit und des Bias jeder Evidenzquelle (S_j).
    - **Inhalt:** Parameter alpha_j (Zuverlässigkeit), beta_j (Bias), tau_j (Transparenz). Berechnung des Qualitäts-Scores q_j=f(alpha_j,beta_j,tau_j).
    - **Visuell:** Ein Block mit drei Sub-Parametern und einer Funktion f.
    - **Verbindung:** Pfeil von hier zu "Evidenzgewichtung".
4. **Sapere-Aude-Faktor (Kollektive Kritische Kapazität C_soc)**
    - **Beschreibung:** Ein Metaparameter, der die Qualität der Bewertungsprozesse im System beeinflusst.
    - **Visuell:** Eine separate, übergreifende Steuergröße (z.B. eine Wolke oder ein vertikaler Balken), die Pfeile zu "Quellenbewertung" und "Bayes'sche Aktualisierung" sendet, um deren Effizienz zu modulieren.
5. **Evidenzgewichtung (omega_i)**
    - **Beschreibung:** Kombination der intrinsischen Evidenzstärke mit der Quellenqualität.
    - **Inhalt:** Berechnung von omega_i=g(e_istrength,q_S(i)).
    - **Visuell:** Ein kleinerer Block, der Eingaben von Evidenz und Quellenbewertung erhält.
6. **Bayes'sche Aktualisierung (Inferenz-Engine)**
    - **Beschreibung:** Der Kernprozess des Glaubens-Updates.
    - **Inhalt:** Iterative Anwendung von P_new(H_k|e_i)=fracP(e_i|H_k)cdotP_old(H_k)P(e_i) und Aggregation zu P_final(H_k).
    - **Visuell:** Der größte Block in der Mitte, mit:
        - Einem Eingangspfeil für P_old(mathcalH) (Rückkopplung).
        - Einem Eingangspfeil für gewichtete Evidenz (omega_i).
        - Einem Ausgangspfeil für P_new(mathcalH) / P_final(mathcalH).
        - Eine interne Rückkopplungsschleife, die den iterativen Charakter

symbolisiert.

7. **Epistemische Resilienz (R_E)**
    - **Beschreibung:** Eine emergente Eigenschaft des gesamten Systems, die durch Redundanz (K_R), Adaptivität (K_A) und Robustheit (K_B) gesteuert wird.
    - **Visuell:** Eine umgebende Schicht oder eine transparente Box, die die Kernprozesse der BEP umschließt, mit den drei Parametern K_R,K_A,K_B, die ihre Stärke symbolisieren.
8. **Entscheidungsfindung ($D^*$)**
    - **Beschreibung:** Ableitung einer optimalen Entscheidung basierend auf P_final(mathcalH) und einer Nutzenfunktion.
    - **Inhalt:** $D^* = \\arg\\max_D \\sum P_{final}(H_k) \\cdot U(D, H_k)$.
    - **Visuell:** Eine Endbox, die die Konsequenz des Bayes'schen Prozesses darstellt.
9. **Feedback zur Realität / Lernschleife**
    - **Beschreibung:** Der Einfluss der getroffenen Entscheidung auf die Realität und die Möglichkeit, daraus zu lernen, um die Parameter des Modells (z.B. P_0(mathcalH), oder die Schätzung von alpha_j,beta_j) anzupassen.
    - **Visuell:** Ein Pfeil von "Entscheidungsfindung" zurück in den "Hypothesenraum" oder zu "Quellenbewertung", um eine geschlossene Systemschleife zu zeigen.

**Farbcodierung (Beispiel):**

- Blau/Grün: Prozesse und Parameter, die zur Stärkung der Epistemischen Souveränität beitragen (z.B. C_soc,R_E).
- Rot/Orange: Störfaktoren oder potenzielle Schwachstellen (z.B. Desinformation D, Bias beta_j).
- Grau/Neutral: Neutrale Informationstransformation.

Ein solches Diagramm würde die BEP nicht nur als Sammlung von Formeln, sondern als **dynamisches, selbstkorrigierendes System** visualisieren, das auf die Förderung einer informierten und resilienten Gesellschaft abzielt.

---

# 4. Open-Source-Simulationsvorlage (Python-Sketch)

Python

```
# MOD-BEP-MATH-2025: Open-Source Simulationsvorlage (Python-Sketch)
# Basierend auf der Mathematischen Formalisierung der Bochumer Evidenzpraxis (BEP)
# Ziel: Simulation von Belief-Updating unter Unsicherheit und Bias

import numpy as np
from collections import defaultdict
```

```
# --- 1. Konfiguration des Hypothesenraums ---
class HypothesisSpace:
    def __init__(self, hypotheses: list[str], initial_probs: list[float] = None):
        """
        Initialisiert den Hypothesenraum.
        hypotheses: Liste der Hypothesennamen (z.B. ["H1", "H2"]).
        initial_probs: Optionale Startwahrscheinlichkeiten (Prior).
                       Wenn None, wird eine uniforme Verteilung angenommen.
        """
        self.hypotheses = hypotheses
        self.num_hypotheses = len(hypotheses)
        if initial_probs is None:
            self.probabilities = np.ones(self.num_hypotheses) / self.num_hypotheses
        else:
            if not np.isclose(sum(initial_probs), 1.0):
                raise ValueError("Initial probabilities must sum to 1.")
            self.probabilities = np.array(initial_probs)
        self.history = [self.probabilities.copy()] # Speichert den Verlauf der Wahrscheinlichkeiten

    def get_entropy(self) -> float:
        """Berechnet die Shannon-Entropie des aktuellen Wahrscheinlichkeitsvektors."""
        # Vermeide log(0) für Hypothesen mit P=0
        positive_probs = self.probabilities[self.probabilities > 0]
        if len(positive_probs) == 0:
            return 0.0 # Falls keine positiven Wahrscheinlichkeiten
        return -np.sum(positive_probs * np.log2(positive_probs))

    def update_probabilities(self, new_probs: np.ndarray):
        """Aktualisiert die Hypothesen-Wahrscheinlichkeiten und speichert den Verlauf."""
        if not np.isclose(sum(new_probs), 1.0) or (new_probs < 0).any():
            raise ValueError("Updated probabilities must sum to 1 and be non-negative.")
        self.probabilities = new_probs
        self.history.append(self.probabilities.copy())

# --- 2. Modellierung von Evidenzquellen ---
class EvidenceSource:
    def __init__(self, name: str, reliability: float, bias: float, transparency: float):
        """
        Initialisiert eine Evidenzquelle.
        name: Name der Quelle.
        reliability (alpha_j): Zuverlässigkeit [0,1].
        bias (beta_j): Bias [-1,1]. Positiv für Pro-Bias, Negativ für Contra-Bias.
        transparency (tau_j): Transparenz [0,1].
```

```
        """
        if not (0 <= reliability <= 1 and -1 <= bias <= 1 and 0 <= transparency <= 1):
            raise ValueError("Parameters must be within specified ranges.")
        self.name = name
        self.reliability = reliability
        self.bias = bias
        self.transparency = transparency

    def get_quality_score(self) -> float:
        """Berechnet den Qualitäts-Score der Quelle q_j = f(alpha_j, beta_j, tau_j)."""
        # Eine einfache Beispiel-Funktion für q_j: Zuverlässigkeit * (1 - Abs(Bias)) * Transparenz
        # Bias reduziert die Qualität, Transparenz modifiziert die Gewissheit über Alpha/Beta
        # Für komplexere Modelle könnte f komplexer sein oder sich an Csoc anpassen.
        return self.reliability * (1 - abs(self.bias)) * self.transparency

# --- 3. Die Bochumer Evidenzpraxis (BEP) Klasse ---
class BEP_Model:
    def __init__(self, hypothesis_space: HypothesisSpace):
        self.hypothesis_space = hypothesis_space
        self.sources = {} # Dict[str, EvidenceSource]

    def add_source(self, source: EvidenceSource):
        self.sources[source.name] = source

    def evaluate_evidence(self,
                          evidence_text: str,
                          source_name: str,
                          likelihoods_given_hypotheses: dict[str, float], # P(e_i|H_k)
                          evidence_strength: float = 1.0) -> np.ndarray:
        """
        Evaluiert eine einzelne Evidenz und aktualisiert die Hypothesen-Wahrscheinlichkeiten.
        evidence_text: Text der Evidenz (für Logging/Kontext).
        source_name: Name der Quelle der Evidenz.
        likelihoods_given_hypotheses: Dictionary {hypothesis_name: P(e_i|H_k)}.
                                      Dies müsste vom Nutzer/Experten eingegeben werden
                                      oder durch ein NLP-Modell geschätzt werden.
        evidence_strength: Intrinsische Stärke/Qualität der Evidenz [0,1].
        """
        if source_name not in self.sources:
            raise ValueError(f"Source '{source_name}' not registered.")
        source = self.sources[source_name]

        # 1. Quelle bewerten
```

```
        source_quality = source.get_quality_score()

        # 2. Evidenz gewichten (omega_i)
        # Hier könnte Bias noch stärker eingehen, z.B. wenn Beta > 0, P(e_i|H_k) wird überbewertet.
        # Für diese Skizze nutzen wir nur den quality_score für das Gewicht des gesamten Likelihood-Terms.
        weighted_likelihoods = np.array([
            likelihoods_given_hypotheses.get(h, 0.0) # P(e_i|H_k)
            for h in self.hypothesis_space.hypotheses
        ])

        # Bayesianische Aktualisierung (Formula 7 und 8)
        # P(H_k | e_i) = P(e_i | H_k) * P(H_k) / P(e_i)
        # P(e_i) ist der Normalisierungsfaktor, Summe( P(e_i|H_k) * P(H_k) )
        prior_probs = self.hypothesis_space.probabilities

        # Berechnung des Gewichts für diesen einzelnen Evidenz-Update-Schritt.
        # Hier wird die 'quality_score' als Exponent für den Likelihood-Term verwendet,
        # um schwächere/verzerrtere Quellen weniger stark in die Aktualisierung einfließen zu lassen.
        # Ein bias > 0 könnte z.B. zu einer leichten Verschiebung der Likelihoods führen.
        # Für diese einfache Skizze verwenden wir es als Skalierungsfaktor für die Relevanz.
        effective_likelihoods = weighted_likelihoods ** source_quality

        marginal_prob_e = np.sum(effective_likelihoods * prior_probs)

        if marginal_prob_e == 0: # Vermeidet Division durch Null
            print(f"Warning: Evidence '{evidence_text}' from '{source_name}' has no support (P(e_i)=0). No update.")
            return self.hypothesis_space.probabilities.copy()

        new_probs = (effective_likelihoods * prior_probs) / marginal_prob_e

        self.hypothesis_space.update_probabilities(new_probs)
        print(f"--- Evidenz '{evidence_text}' von '{source_name}' ---")
        print(f"Quelle Qualität: {source_quality:.2f}")
        print("Neue Hypothesen-Wahrscheinlichkeiten:", np.round(self.hypothesis_space.probabilities, 3))
        return self.hypothesis_space.probabilities.copy()

    def make_decision(self, utility_matrix: np.ndarray) -> tuple[int, float]:
        """
```

```
        Trifft eine Entscheidung basierend auf der aktuellen Hypothesen-Verteilung und einer Nutzenmatrix.
        utility_matrix: Matrix [num_decisions, num_hypotheses], U(D, H_k).
        Gibt den Index der optimalen Entscheidung und den erwarteten Nutzen zurück.
        """
        expected_utilities = np.dot(utility_matrix, self.hypothesis_space.probabilities)
        optimal_decision_idx = np.argmax(expected_utilities)
        max_utility = expected_utilities[optimal_decision_idx]
        return optimal_decision_idx, max_utility

# --- 4. Sapere-Aude-Faktor als Metaparameter (Simulation) ---
def simulate_sapere_aude_impact(initial_csoc: float, final_csoc: float, bep_model: BEP_Model, scenario_data: list):
    """
    Simuliert den Einfluss des Sapere-Aude-Faktors (Csoc) auf die Bewertungsparameter.
    Hier wird Csoc direkt die Qualität der Quellenbewertung beeinflussen.
    """
    print(f"\n--- Simulation des Sapere-Aude-Einflusses (Csoc von {initial_csoc} zu {final_csoc}) ---")

    # Speichere die originalen Quellenparameter, um sie zurücksetzen zu können
    original_source_params = {name: (s.reliability, s.bias, s.transparency) for name, s in bep_model.sources.items()}

    # Simuliere Schritte der Csoc-Entwicklung
    num_steps = 3
    for step, csoc_val in enumerate(np.linspace(initial_csoc, final_csoc, num_steps)):
        print(f"\n--- Schritt {step+1}: Csoc = {csoc_val:.2f} ---")

        # Anpassung der Quellenparameter basierend auf Csoc
        for source_name, source in bep_model.sources.items():
            # Höhere Csoc verbessert die "wahrgenommene" Zuverlässigkeit,
            # wenn die Quelle objektiv gut ist, oder reduziert den Einfluss von Bias.
            # Diese Anpassungen sind beispielhaft und müssten empirisch fundiert werden.
            source.reliability = min(1.0, original_source_params[source_name][0] + (csoc_val - initial_csoc) * 0.1)
            source.bias = original_source_params[source_name][1] * (1 - (csoc_val - initial_csoc) * 0.5) # Bias-Effekt reduziert
            source.transparency = min(1.0, original_source_params[source_name][2] + (csoc_val - initial_csoc) * 0.1)

        # Setze den Hypothesenraum für jeden Csoc-Schritt auf den Startzustand zurück
        bep_model.hypothesis_space.probabilities =
```

```
bep_model.hypothesis_space.history[0].copy()
        bep_model.hypothesis_space.history =
[bep_model.hypothesis_space.probabilities.copy()] # Reset History

        # Jetzt die Evidenz erneut durchlaufen mit den angepassten Quellqualitäten
        print(f"Modell aktualisiert für Csoc={csoc_val:.2f}...")
        for data in scenario_data:
            bep_model.evaluate_evidence(data['text'], data['source'], data['likelihoods'],
data['strength'])
        print(f"Endgültige Verteilung bei Csoc={csoc_val:.2f}:
{np.round(bep_model.hypothesis_space.probabilities, 3)}")

    # Parameter der Quellen auf den ursprünglichen Zustand zurücksetzen (für weitere
Nutzungen)
    for name, params in original_source_params.items():
        s = bep_model.sources[name]
        s.reliability, s.bias, s.transparency = params


# --- Simulationsbeispiel ---
if __name__ == "__main__":
    # 1. Hypothesen definieren
    hypotheses = ["Klimawandel ist menschengemacht (H1)", "Klimawandel ist natürlich (H2)",
"Klimawandel existiert nicht (H3)"]
    initial_probs = [0.8, 0.15, 0.05] # Expertenmeinung als Startpunkt

    h_space = HypothesisSpace(hypotheses, initial_probs)
    print("Initialer Hypothesenraum:", h_space.hypotheses)
    print("Start-Wahrscheinlichkeiten:", np.round(h_space.probabilities, 3))
    print("Start-Entropie:", h_space.get_entropy())

    bep_system = BEP_Model(h_space)

    # 2. Quellen hinzufügen (Beispiel für NGO-Kritik)
    bep_system.add_source(EvidenceSource("Wissenschaftsakademie", 0.95, 0.0, 1.0))
    bep_system.add_source(EvidenceSource("Industrieverband_A", 0.7, 0.4, 0.6)) # Hoher Bias,
mittlere Transparenz
    bep_system.add_source(EvidenceSource("NGO_Umwelt_X", 0.85, -0.3, 0.4)) # Bias gegen
Industrie, geringe Transparenz
    bep_system.add_source(EvidenceSource("Soziale_Medien_Nutzer", 0.3, 0.5, 0.2))

    # 3. Evidenzschritte simulieren
    print("\n--- Simulation der Evidenzbewertung ---")
```

```
    scenario_data_main = [
        {'text': "Neue globale Temperaturdaten bestätigen Erwärmungstrend.", 'source':
"Wissenschaftsakademie", 'likelihoods': {"Klimawandel ist menschengemacht (H1)": 0.9,
"Klimawandel ist natürlich (H2)": 0.1, "Klimawandel existiert nicht (H3)": 0.05}, 'strength': 0.9},
        {'text': "Klimamodelle sind unsicher und übertreiben Effekte.", 'source':
"Industrieverband_A", 'likelihoods': {"Klimawandel ist menschengemacht (H1)": 0.3,
"Klimawandel ist natürlich (H2)": 0.6, "Klimawandel existiert nicht (H3)": 0.5}, 'strength': 0.6},
        {'text': "Umweltschäden durch fossile Brennstoffe sind katastrophal und beweisen H1.",
'source': "NGO_Umwelt_X", 'likelihoods': {"Klimawandel ist menschengemacht (H1)": 0.95,
"Klimawandel ist natürlich (H2)": 0.05, "Klimawandel existiert nicht (H3)": 0.01}, 'strength':
0.8},
        {'text': "Das Klima ändert sich immer, das ist Panikmache.", 'source':
"Soziale_Medien_Nutzer", 'likelihoods': {"Klimawandel ist menschengemacht (H1)": 0.1,
"Klimawandel ist natürlich (H2)": 0.4, "Klimawandel existiert nicht (H3)": 0.9}, 'strength': 0.2}
    ]

    for data in scenario_data_main:
        bep_system.evaluate_evidence(data['text'], data['source'], data['likelihoods'],
data['strength'])

    print("\nFinaler Hypothesen-Zustand nach allen Evidenzen:",
np.round(h_space.probabilities, 3))
    print("Finale Entropie:", h_space.get_entropy())

    # 4. Entscheidungsfindung (Beispiel: Investitionsentscheidung)
    # Zeilen: Entscheidungen (z.B. [Invest in erneuerbare, Invest in Anpassung, Nichts tun])
    # Spalten: Hypothesen (H1, H2, H3)
    utility_matrix = np.array([
        [100, 20, -50],  # Nutzen für 'Invest in erneuerbare' bei H1, H2, H3
        [50, 80, 10],   # Nutzen für 'Invest in Anpassung' bei H1, H2, H3
        [-30, -10, 50]  # Nutzen für 'Nichts tun' bei H1, H2, H3
    ])

    optimal_decision_idx, max_utility = bep_system.make_decision(utility_matrix)
    print(f"\nOptimale Entscheidung (Index): {optimal_decision_idx}")
    print(f"Erwarteter Nutzen: {max_utility:.2f}")

    # 5. Simulation des Sapere-Aude-Einflusses
    # Setzt den Hypothesenraum vor der Sapere-Aude-Simulation auf den ursprünglichen
Zustand zurück
    bep_system.hypothesis_space.probabilities = np.array(initial_probs).copy()
    bep_system.hypothesis_space.history =
```

[bep_system.hypothesis_space.probabilities.copy()]

simulate_sapere_aude_impact(0.5, 0.9, bep_system, scenario_data_main) # Start bei mittlerem Csoc, erhöhe es

[^1]:
Schoresch Davoodi, "Fakten und Fiktionen – Wie die Gesellschaft durch Unsicherheit gestresst wird" (Address at Hack the Promise Festival 2024, Basel, September 29, 2024; published by Pirate Parties International, July 1, 2025). This address outlines the core epistemological challenges and the conceptual need for a structured evidence practice.
[^2]:
For a foundational understanding of information entropy and its application in uncertainty quantification, see Shannon (1948). The relationship between entropy and knowledge uncertainty is well-established in information theory and cognitive science.
[^3]:
The concept of resilience in complex systems has been extensively developed across various disciplines. For an overview relevant to socio-political contexts, see Walker and Salt (2012) or Folke (2006). Davoodi's application specifically highlights "epistemic" resilience.
[^4]:
The critical analysis of NGOs' influence and accountability in democratic discourse is a growing area of academic inquiry. For broader perspectives on civil society and its evolving role, see Cohen and Arato (1992) or Kaldor (2003). Davoodi's critique focuses on their discursive power and transparency from an epistemological standpoint.